

The Application of Artificial Intelligence in Waste Classification as an Effort In Plastic Waste Management

Aplikasi Kecerdasan Artifisial dalam Klasifikasi Sampah sebagai Upaya Pengolahan Sampah Plastik

Latifah Listyalina¹, Ratri Retno Utami², Uma Fadzilia Arifin³, Naimah Putri⁴

^{1,2,3} Teknologi Pengolahan Karet dan Plastik, Politeknik ATK Yogyakarta, Indonesia

⁴ Teknologi Pengolahan Kulit, Politeknik ATK Yogyakarta, Indonesia

^{1*}latifah.listyalina@atk.ac.id, ²ratriretnou@kemenperin.go.id, ³umafadzilia@atk.ac.id,

⁴naimah-p@kemenperin.go.id

*: Penulis korespondensi (corresponding author)

Informasi Artikel

Received: February 2024

Revised: May 2024

Accepted: May 2024

Published: June 2024

Abstract

Purpose: Sorting waste before it is deposited in the Final Disposal Site (TPA) is crucial to reduce the increasing amount of waste accumulation each year. This issue can be addressed by implementing machines capable of automatically sorting waste.

Design/methodology/approach: This research is quantitative and utilizes secondary data, namely image data of various types of waste. The images will be classified into organic and inorganic waste using a deep learning model. The measurement conducted involves assessing the accuracy of the designed deep learning model in classifying waste images into appropriate categories.

Fondings/results: Based on the available dataset, waste identification will be performed, including food waste, paper, wood, leaves, electronic waste, metal, plastic, and bottles. The overall accuracy of the model is 94.42%, indicating that the model correctly classifies 94.42% of waste samples.

Originality/value/state of the art: This research can classify 8 types of waste classes successfully using deep learning.

Abstrak

Tujuan: Pemilahan sampah sebelum ditampung ke Tempat Pemuangan Akhir (TPA) sangat penting untuk mengurangi jumlah penimbunan sampah yang terus meningkat setiap tahunnya. Permasalahan ini dapat ditangani dengan mengimplementasikan mesin yang dapat memilah sampah dengan otomatis.

Keywords: deep learning, waste, identification

Kata kunci: deep learning, sampah, identifikasi

Perancangan/metode/pendekatan: Penelitian ini berjenis kuantitatif dan menggunakan data sekunder, yakni data citra jenis-jenis sampah. Citra akan diklasifikasikan ke jenis sampah organik dan sampah anorganik dengan bantuan model deep learning. Pengukuran yang dilakukan berupa pengukuran tingkat akurasi model deep learning yang dirancang dalam mengklasifikasikan citra sampah ke jenis-jenis sampah yang sesuai.

Hasil: Sesuai dataset yang ada, akan dilakukan identifikasi sampah yang akan digunakan, yaitu sampah sisa makanan, kertas, kayu, dan daun serta sampah elektronik, logam, plastic, dan botol. Akurasi keseluruhan model adalah 94,42%, yang berarti bahwa model tersebut mengklasifikasikan dengan benar 94,42% sampel limbah

Keaslian/ *state of the art*: Penelitian ini dapat mengklasifikasikan 8 jenis kelas sampah yang berhasil diklasifikasikan otomatis menggunakan deep learning.

1. Pendahuluan

Sampah adalah zat sisa yang sudah tidak terpakai dan dibuang yang dihasilkan dari suatu proses produksi domestik (rumah tangga) atau industri. Jumlah timbunan sampah di Indonesia dalam setahun sekitar 67,8 juta ton, jumlah itu akan terus bertambah seiring dengan pertumbuhan jumlah penduduk di Indonesia. Hal ini membuat Tempat Penampungan Akhir (TPA) penuh karena tumpukan sampah yang berlebih yang dapat membuat kerusakan di lingkungan sekitar. Dalam Undang-undang No 18 Tahun 2008 tentang Pengelolaan Sampah, disebutkan bahwa sampah adalah sisa kegiatan sehari-hari manusia atau proses alam yang berbentuk padat atau semi padat berupa zat organik atau anorganik bersifat dapat terurai atau tidak dapat terurai yang dianggap sudah tidak berguna lagi dan dibuang ke lingkungan [1], [2].

Meningkatnya jumlah sampah tidak diimbangi oleh meningkatnya kesadaran masyarakat untuk mengusahakan lingkungan hidup yang bersih dan sehat, terlebih ialah bahayanya sampah plastik. Di samping itu, kemampuan pemerintah dalam pengelolaan sampah juga belum mencapai hasil yang optimal, terlihat dari adanya dampak yang ditimbulkan dari sampah yang semakin hari semakin menumpuk. [3]–[5][6][7]. Jika tidak tertangani dengan baik maka pada masa mendatang sampah akan menjadi masalah serius karena faktor-faktor yang menyebabkan timbulan sampah seperti jumlah penduduk, keadaan sosial ekonomi serta kemajuan teknologi yang diperkirakan akan mengalami peningkatan yang signifikan.

Kendala ketika melakukan pengelolaan sampah adalah pemilahan sampah terutama dengan sampah organik karena faktor bau. Sampah organik dan anorganik memiliki lama penguraian yang berbeda. Sampah organik memiliki waktu yang lebih cepat dibandingkan dengan sampah anorganik. Oleh sebab itu sampah organik dan anorganik memiliki cara penanganan daur ulang yang berbeda pula. Pemilahan sampah sebelum ditampung ke Tempat Pemuangan Akhir (TPA) sangat penting untuk mengurangi jumlah penimbunan sampah yang terus meningkat setiap tahunnya [8]–[11]. Pemilahan sampah dengan melibatkan *computer vision* memiliki beberapa keunggulan dibandingkan dengan pemilahan manual. Teknologi ini dapat memproses dan

memilah sampah dalam jumlah besar dengan sangat cepat dan konsisten, jauh melebihi kemampuan manusia. Sistem ini dapat dilatih untuk mengenali berbagai jenis sampah dengan tingkat akurasi yang tinggi menggunakan algoritma pembelajaran mesin. Ini mengurangi kesalahan dalam pemilahan. Pemilahan manual memerlukan waktu yang lebih lama karena keterbatasan fisik manusia dan potensi kelelahan. Manusia dapat membuat kesalahan, terutama jika jenis sampah yang dihadapi sangat bervariasi atau dalam jumlah yang besar. Setelah sistem diimplementasikan, biaya operasionalnya relatif rendah dibandingkan dengan gaji dan tunjangan untuk tenaga kerja manual yang diperlukan dalam jumlah besar. Pengurangan keterlibatan manusia dalam proses ini dapat mengurangi risiko kesehatan yang terkait dengan penanganan sampah, seperti paparan bahan berbahaya dan cedera fisik. Pekerja manual berisiko terkena berbagai bahaya, termasuk benda tajam, bahan kimia berbahaya, dan penyakit dari sampah organik. Sistem dapat bekerja 24/7 tanpa istirahat, memastikan operasi yang konsisten dan berkelanjutan. Pekerja manusia memerlukan istirahat dan memiliki batas waktu kerja, yang berarti ada downtime dalam proses pemilahan. Teknologi ini dapat mengumpulkan data yang berguna tentang jenis dan volume sampah, yang bisa dianalisis untuk meningkatkan efisiensi dan mengembangkan strategi pengelolaan sampah yang lebih baik. Dengan mempertimbangkan faktor-faktor di atas, jelas bahwa integrasi *computer vision* dalam pemilahan sampah menawarkan solusi yang lebih efektif dan efisien dibandingkan dengan metode manual.

Metode yang digunakan dalam penelitian pertama menggunakan metode Convolutional Neural Network (CNN) yang dapat digunakan untuk mendeteksi dan mengenali objek dalam gambar, yang dapat digunakan untuk membuat sistem klasifikasi sampah otomatis. Secara umum, CNN menggunakan proses konvolusi dengan memindahkan kernel konvolusi (filter) berukuran tertentu ke gambar, komputer mendapatkan informasi representatif baru dari hasil perkalian bagian gambar tersebut dengan filter yang digunakan. Hasil pengujian menunjukkan bahwa metode CNN dapat mengklasifikasikan sampah anorganik dengan akurasi 96% dan sampah organik dengan akurasi 62% [12]. Penelitian kedua mencoba membuat prototipe tempat sampah yang mengklasifikasikan sampah kantor berupa botol plastik, kaleng, dan kertas. Sistem kemudian secara otomatis menempatkan sampah tersebut ke dalam wadah kategori mereka. Untuk melakukan tugas klasifikasinya, digunakan metode arsitektur deep learning Xception, yang diterapkan pada prosesor sistem, yaitu NVIDIA Jetson Nano. Sistem ini menghasilkan output, yaitu gerakan lengan pemilah. Lengan pemilah bergerak ke kiri jika hasil klasifikasi adalah sampah botol plastik, bergerak ke kanan untuk sampah kaleng, dan tetap di tengah untuk sampah kertas. Untuk pengujian klasifikasi objek sampah dalam sistem, hasil akurasi yang diperoleh sebesar 91,67% dan waktu komputasi rata-rata untuk klasifikasi adalah 0,06385 detik. Pengujian integrasi juga dilakukan pada sistem yang menghasilkan akurasi sebesar 97,22% [13].

Proses pemisahan sampah dapat diterapkan menggunakan model Convolutional Neural Network. Convolutional Neural Network (CNN) adalah salah satu metode deep learning yang dapat digunakan untuk mendeteksi dan mengenali objek pada gambar digital. Penelitian ini akan menentukan model CNN (Convolutional Neural Network) yang memiliki akurasi tinggi dalam pengklasifikasian sampah menggunakan metode tensorflow. Dalam penelitian ini, analisis CNN yang cocok untuk klasifikasi pemilahan sampah akan dilakukan secara optimal. Sehingga algoritma ini dapat digunakan untuk implementasi pemisahan sampah otomatis menggunakan sistem. Penelitian ini bertujuan untuk mengurangi waktu dan menyederhanakan proses pemisahan sampah pada tahap daur ulang sampah. Untuk memaksimalkan proses daur ulang sampah, klasifikasi sampah organik dan anorganik dapat dilakukan. Proses klasifikasi

menggunakan model Convolutional Neural Network. Penelitian dengan pembagian data latih sebesar 80% dan data uji sebesar 20%, menggunakan Convolutional Neural Network dengan dense layer sebanyak 128 dan epoch sebanyak 50 menghasilkan akurasi penuh pada data latih dan data uji. Dengan menggunakan model Convolutional Neural Network, dapat dilakukan klasifikasi gambar sampah anorganik dan organik [14]. Bank Sampah di Kabupaten Polewali Mandar adalah salah satu solusi dalam menangani masalah sampah. Namun, dalam prosesnya, terutama pada sampah plastik, Bank Sampah belum dapat membedakan berbagai jenis plastik yang sebenarnya memiliki variasi nilai jual. Dari hasil pengujian, akurasi KNN pada data pengujian mencapai 88%. Pengujian dilakukan menggunakan 3 metode yaitu metode Cross Tabulation, Classification Metrics, dan Cross Validation. Dari hasil pengujian diperoleh tingkat akurasi KNN terhadap data testing sebesar 88%. Nilai akurasi yang diperoleh cenderung rendah, penyebabnya karena dataset yang digunakan jumlahnya sedikit, selain itu proses pembobotan yang masih manual menyebabkan rentang nilai dataset cenderung dekat dan mirip satu dan lainnya [15]

Dari penelitian [12]–[15], diperoleh beberapa hasil penelitian seperti performa pengujian masih ada di bawah 80%, dan dataset yang terbatas. Kontribusi dalam penelitian ini selain menjembatani antara mesin eksekusi sampah dengan sampah timbunan sampah yang ada, juga akan dilakukan beberapa perbaikan dari kekurangan penelitian sebelumnya. Identifikasi yang dimaksud di sini ialah klasifikasi delapan jenis kelas sampah lebih rinci di mana banyaknya kelas sampah pada penelitian ini merupakan kelebihan dari peneliti-peneliti terdahulu.

2. Metode/Perancangan

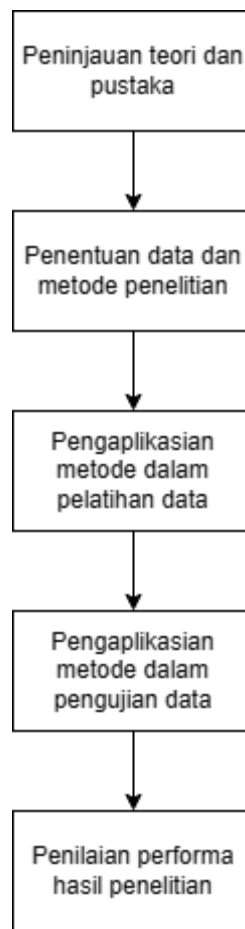
Populasi pada penelitian ini adalah sampah organik dan anorganik. Sampel diambil secara acak oleh seorang peneliti dan hasil sampling diunggah ke <https://www.kaggle.com/datasets/aashidutt3/waste-segregation-image-dataset>. Penelitian ini akan dilakukan pada laptop dengan prosesor Core-i3 dan RAM 8GB dan virtual GPU yang disewa dari Google Colab Pro. Adapun tahapan dalam penelitian ini diilustrasikan pada Gambar 2 di bawah dan diuraikan sebagai berikut. Pada metode dibahas tentang metode, tahapan, maupun model yang digunakan dalam penelitian yang dilakukan. Berikut merupakan contoh data masing-masing kelas sampah.





Gambar 1. Contoh dataset klasifikasi sampah (a) makanan (b) daun (c) kertas (d) kayu (e) elektronik (f) kaleng (g) kresek (h) botol plastik [7]

Adapun metode penelitian yang telah dijelaskan di atas, digambarkan sebagai berikut.



Gambar 2. Tahapan Penelitian

Dari bagan alur penelitian di atas, telah dibagi beberapa tahapan penelitian ini. Tahap pertama dilakukan dengan peninjauan teori dan pustaka yang terkait dengan penelitian ini. Teori yang dimaksud ialah dasar-dasar teori yang terkait pada penelitian ini, seperti hal-hal terkait sampah ataupun deep learning sedangkan pustaka yang dimaksud adalah beberapa penelitian terdahulu yang terkait dengan penelitian ini di mana akan menjadi masukan dan dasar dalam melakukan penelitian ini.

Tahap kedua adalah tahapan dalam menentukan data dan metode penelitian. Penentuan ini disesuaikan dengan judul yang telah diusung, seperti data yang dibutuhkan ialah data sampah yang sudah diklasifikasikan menurut kebutuhan penelitian ini di mana data tersebut tersedia dalam dataset sekunder Kaggle.com. Untuk metode penelitian, akan disesuaikan metode deep learning yang mampu mengidentifikasi kelas yang dibutuhkan. Jumlah citra sampah keseluruhan dan jumlah citra sampah di setiap kelas telah dibagi di mana pembagian data menjadi data latih dan uji dilakukan sesuai situs penyedia data sekunder, yaitu sebagai berikut.

- a. Data Latih
 1. sampah makanan sebanyak 10.100 data
 2. sampah daun sebanyak 1179 data
 3. sampah kertas sebanyak 860 data
 4. sampah kayu sebanyak 593 data
 5. sampah elektronik sebanyak 180 data
 6. sampah logam sebanyak 670 data
 7. sampah tas plastik sebanyak 200 data
 8. sampah botol plastik sebanyak 417 data
- b. Data Uji
 1. sampah makanan sebanyak 229 data
 2. sampah daun sebanyak 394 data
 3. sampah kertas sebanyak 212 data
 4. sampah kayu sebanyak 59 data
 5. sampah elektronik sebanyak 55 data
 6. sampah logam sebanyak 69 data
 7. sampah tas plastik sebanyak 53 data
 8. sampah botol plastik sebanyak 130 data

Tahap ketiga dan tahap keempat ialah mengaplikasikan metode deep learning yang telah dipilih dari hasil tahap kedua. Keberhasilan pelatihan metode akan menentukan keberhasilan pengujian yang akan digunakan. Hal tersebut akan bergantung pada koefisien-koefisien yang akan dipilih pada proses pelatihan.

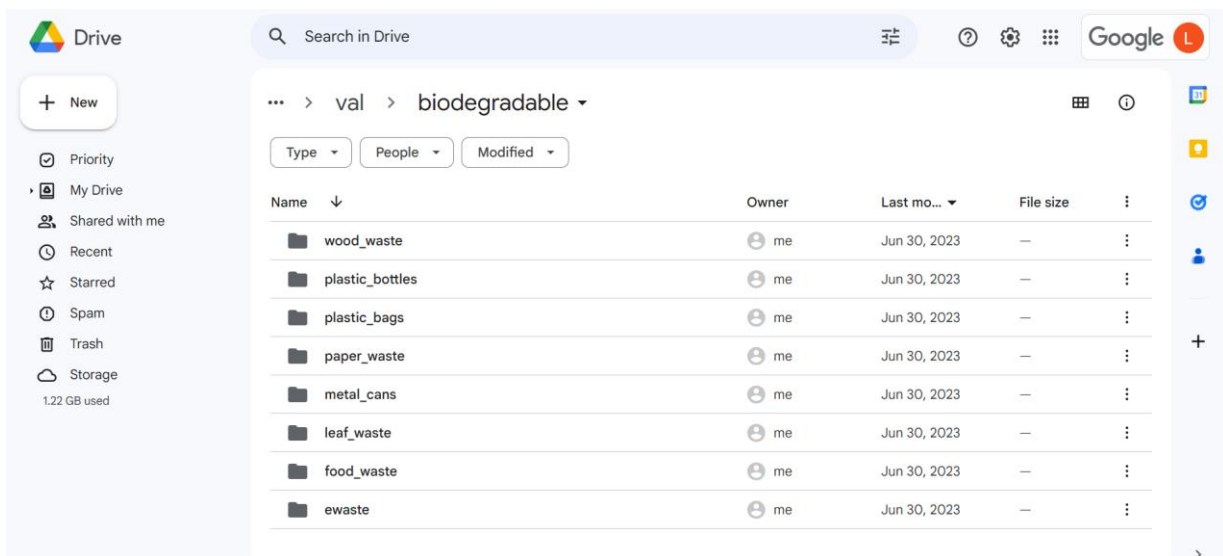
Setelah proses pengujian selesai, tahap kelima merupakan proses penilaian performa hasil pengujian sebelumnya. Hasil kuantitatif tahapan ini menentukan keberhasilan penelitian ini. Baik tidaknya nilai performa penelitian akan menentukan proses publikasi.

3. Hasil dan Pembahasan

Penelitian ini membutuhkan dataset sebagai bahan penelitian. Dataset pada penelitian telah diunduh dari <https://www.kaggle.com/datasets/aashidutt3/waste-segregation-image-dataset>. Digunakan sebanyak kurang lebih 1,2 juta citra data untuk pelatihan dan 1200 citra data pengujian. Keseluruhan data citra di atas, telah terbagi delapan kelas sampah sesuai dengan pakar yang dipaparkan pada situs di atas.

Pada dataset tersebut, dikelaskan menjadi data pelatihan dan data pengujian. Masing-masing kelas tersebut terbagi menjadi berbagai macam sampah, seperti sampah yang dapat terurai secara alami dan sampah yang tidak dapat terurai secara alami. Dari keseluruhan data di atas, telah dilakukan pengunduhan. Kemudian dilakukan pula penyimpanan data hasil pengunduhan

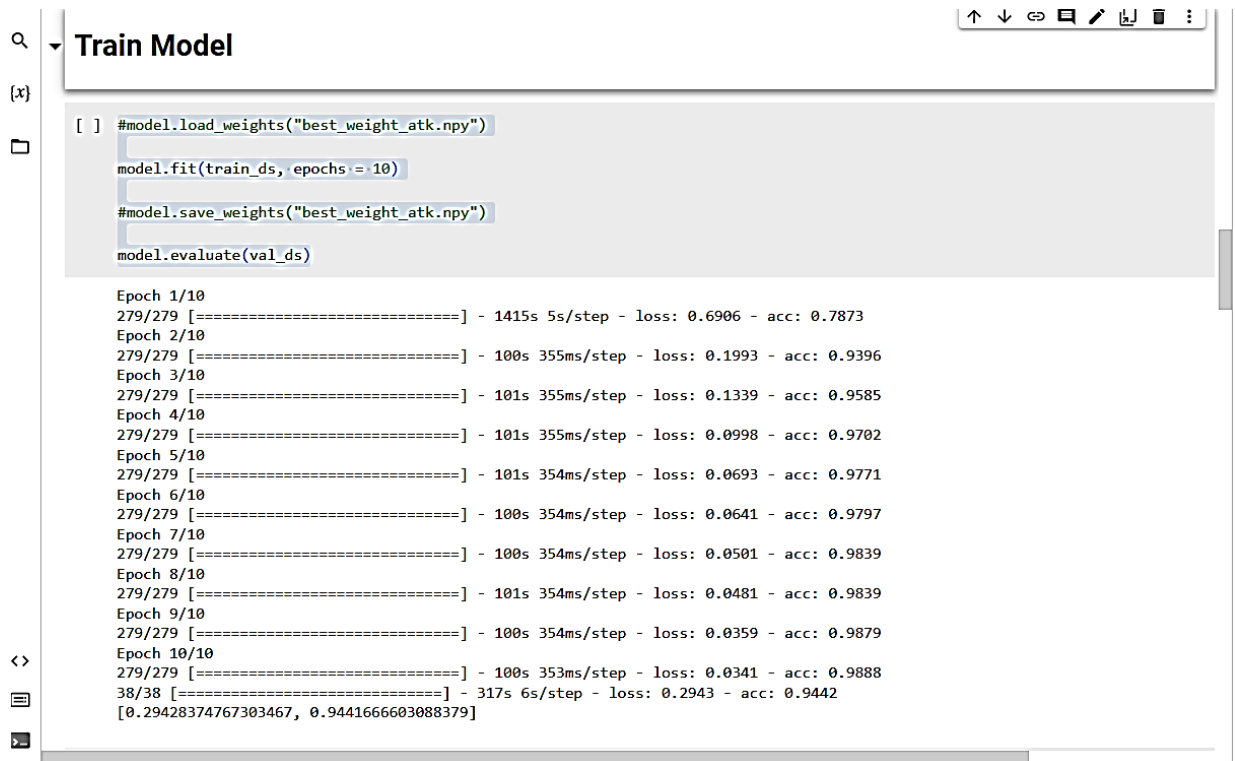
pada GoogleDrive. Hal tersebut dilakukan untuk mempermudah pemanggilan direktori Ketika proses pelatihan dan pengujian. Adapun hal yang dimaksud di atas dipaparkan sebagai berikut.



Gambar 3. Hasil Penyimpanan Data di GoogleDrive

Selanjutnya, dilakukan perancangan algoritma dengan bantuan Phyton dan Google Colab. Setelah dirancang dan ditentukan algoritma yang akan digunakan, akan dilakukan pemanggilan dataset sesuai dengan direktori yang ada di GoogleDrive. Setelah dilakukan proses ini, pelatihan dan pengujian baru dapat dilakukan. Selanjutnya dilakukan proses pemanggilan dataset dengan menambahkan proses augmentasi di mana augmentasi data merupakan proses memodifikasi atau memanipulasi suatu citra, sehingga citra asli dalam bentuk standar akan diubah bentuk dan posisinya. Langkah ini bertujuan agar komputer dapat belajar dan mengenali dari berbagai data yang berbeda-beda sekaligus bisa dimanfaatkan untuk memperbanyak data.

Selanjutnya, akan dilakukan proses pendefinisian model EfficientNet-B0 di mana EfficientNet termasuk salah satu teknik transfer learning yang dikhususkan untuk masalah pengenalan objek atau klasifikasi gambar. EfficientNet adalah serangkaian arsitektur jaringan saraf yang dirancang untuk memberikan keseimbangan optimal antara kinerja dan ukuran model. EfficientNet-B0 adalah varian pertama dari seri EfficientNet, dan itu adalah model dasar dalam keluarga tersebut. Model ini dirancang dengan menggunakan teknik scaling untuk meningkatkan kinerja jaringan dengan memperhatikan faktor-faktor seperti kedalaman (*depth*), lebar (*width*), dan resolusi gambar secara bersamaan. Sedangkan EfficientNet-B0 adalah model dasar yang dapat diubah ukurannya untuk memenuhi kebutuhan kinerja dan sumber daya yang berbeda. Hal tersebut sesuai dengan tujuan penelitian ini, yaitu melakukan klasifikasi sampah berdasarkan gambarnya. Langkah selanjutnya yaitu proses pelatihan data sebanyak 10 epoh menggunakan model algoritma yang telah dipilih. Model EfficientNet-B0 ini dilatih selama 300 epoch dengan batch size 256. Kinerja model EfficientNet-B0 dievaluasi pada berbagai tugas pengenalan gambar, seperti klasifikasi gambar, deteksi objek, dan segmentasi gambar. Model ini mencapai kinerja yang kompetitif dengan model CNN lainnya yang lebih besar dan lebih kompleks. Hasil pelatihan seperti ditunjukkan di bawah ini.



```
[ ] #model.load_weights("best_weight_atk.npy")
model.fit(train_ds, epochs = 10)
#model.save_weights("best_weight_atk.npy")
model.evaluate(val_ds)
```

Epoch 1/10
279/279 [=====] - 1415s 5s/step - loss: 0.6906 - acc: 0.7873
Epoch 2/10
279/279 [=====] - 100s 355ms/step - loss: 0.1993 - acc: 0.9396
Epoch 3/10
279/279 [=====] - 101s 355ms/step - loss: 0.1339 - acc: 0.9585
Epoch 4/10
279/279 [=====] - 101s 355ms/step - loss: 0.0998 - acc: 0.9702
Epoch 5/10
279/279 [=====] - 101s 354ms/step - loss: 0.0693 - acc: 0.9771
Epoch 6/10
279/279 [=====] - 100s 354ms/step - loss: 0.0641 - acc: 0.9797
Epoch 7/10
279/279 [=====] - 100s 354ms/step - loss: 0.0501 - acc: 0.9839
Epoch 8/10
279/279 [=====] - 101s 354ms/step - loss: 0.0481 - acc: 0.9839
Epoch 9/10
279/279 [=====] - 100s 354ms/step - loss: 0.0359 - acc: 0.9879
Epoch 10/10
279/279 [=====] - 100s 353ms/step - loss: 0.0341 - acc: 0.9888
38/38 [=====] - 317s 6s/step - loss: 0.2943 - acc: 0.9442
[0.29428374767303467, 0.9441666603088379]

(a)

❏ ▾ Evaluate Model

```
[ ] model.load_weights('best_weight_atk.npy')

<tensorflow.python.checkpoint.checkpoint.CheckpointLoadStatus at 0x7e81ba17b2b0>

[ ] model.evaluate(val_ds)

38/38 [=====] - 9s 281ms/step - loss: 0.2943 - acc: 0.9442
[0.2942837178707123, 0.9441666603088379]

❶ !pip install pretty-confusion-matrix

Collecting pretty-confusion-matrix
  Downloading pretty_confusion_matrix-0.1.1-py3-none-any.whl (9.6 kB)
Collecting black<22.0,>=21.5b0 (from pretty-confusion-matrix)
  Downloading black-21.12b0-py3-none-any.whl (156 kB)
Collecting flake8<4.0.0,>=3.9.2 (from pretty-confusion-matrix)
  Downloading flake8-3.9.2-py2.py3-none-any.whl (73 kB)
Collecting isort<5.0.0,>=5.8.0 (from pretty-confusion-matrix)
  Downloading isort-5.12.0-py3-none-any.whl (91 kB)
Requirement already satisfied: matplotlib<4.0.0,>=3.5.0 in /usr/local/lib/python3.10/dist-packages (from pretty-confusion-matrix) (3.7.1)
Requirement already satisfied: numpy<2.0.0,>=1.21.4 in /usr/local/lib/python3.10/dist-packages (from pretty-confusion-matrix) (1.23.5)
Requirement already satisfied: pandas<2.0.0,>=1.3.4 in /usr/local/lib/python3.10/dist-packages (from pretty-confusion-matrix) (1.5.3)
Collecting pre-commit<3.0.0,>=2.12.1 (from pretty-confusion-matrix)
  Downloading pre_commit-2.21.0-py2.py3-none-any.whl (281 kB)
Collecting seaborn<0.12.0,>=0.11.2 (from pretty-confusion-matrix)
  Downloading seaborn-0.11.2-py3-none-any.whl (292 kB)
Collecting sklearn<0.1,>=0.0 (from pretty-confusion-matrix)
  Downloading sklearn-0.0.post9.tar.gz (3.6 kB)
  Preparing metadata (setup.py) ... done
Requirement already satisfied: click>=7.1.2 in /usr/local/lib/python3.10/dist-packages (from black<22.0,>=21.5b0->pretty-confusion-matrix) (8.1.7)
Requirement already satisfied: platformdirs>=2 in /usr/local/lib/python3.10/dist-packages (from black<22.0,>=21.5b0->pretty-confusion-matrix) (3.10.0)
Collecting tomli<2.0.0,>=0.2.6 (from black<22.0,>=21.5b0->pretty-confusion-matrix)
  Downloading tomli-1.2.3-py3-none-any.whl (12 kB)
Collecting pathspec<0.11.2,>=0.9.0 (from black<22.0,>=21.5b0->pretty-confusion-matrix)
  Downloading pathspec-0.11.2-py3-none-any.whl (29 kB)
Requirement already satisfied: typing-extensions>=3.10.0.0 in /usr/local/lib/python3.10/dist-packages (from black<22.0,>=21.5b0->pretty-confusion-matrix) (4.5.0)
Collecting mypy_extensions<0.4.3 (from black<22.0,>=21.5b0->pretty-confusion-matrix)
  Downloading mypy_extensions-1.0.0-py3-none-any.whl (4.7 kB)
Collecting pyflakes<2.4.0,>=2.3.0 (from flake8<4.0.0,>=3.9.2->pretty-confusion-matrix)
  Downloading pyflakes-2.3.1-py2.py3-none-any.whl (68 kB)
Collecting pycodestyle<2.8.0,>=2.7.0 (from flake8<4.0.0,>=3.9.2->pretty-confusion-matrix)
  Downloading pycodestyle-2.7.0-py2.py3-none-any.whl (41 kB)
Collecting mccabe<0.7.0,>=0.6.0 (from flake8<4.0.0,>=3.9.2->pretty-confusion-matrix)
  Downloading mccabe-0.6.1-py2.py3-none-any.whl (8.6 kB)
Requirement already satisfied: contourpy>=1.0.1 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (1.1.0)
Requirement already satisfied: cycler>=0.10 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (0.11.0)
Requirement already satisfied: fonttools>=4.22.0 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (4.42.1)
Requirement already satisfied: kiwisolver>=1.0.1 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (1.4.5)
Requirement already satisfied: packaging>=20.0 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (23.1)
Requirement already satisfied: pillow>=6.2.0 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (9.4.0)
Requirement already satisfied: pyparsing>=2.3.1 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (3.1.1)
Requirement already satisfied: python-dateutil>=2.7 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (2.8.2)
Requirement already satisfied: pytz>=2020.1 in /usr/local/lib/python3.10/dist-packages (from matplotlib<4.0.0,>=3.5.0->pretty-confusion-matrix) (2023.3.post1)
Collecting cfv>=2.0.0 (from pre-commit<3.0.0,>=2.12.1->pretty-confusion-matrix)
  Downloading cfv-3.4.0-py2.py3-none-any.whl (7.2 kB)
Collecting identify<1.0.0 (from pre-commit<3.0.0,>=2.12.1->pretty-confusion-matrix)
  Downloading identify-2.5.29-py2.py3-none-any.whl (98 kB)
Collecting nodeenv>=0.11.1 (from pre-commit<3.0.0,>=2.12.1->pretty-confusion-matrix)
  Downloading nodeenv-1.8.0-py2.py3-none-any.whl (22 kB)
Requirement already satisfied: pyyaml>=5.1 in /usr/local/lib/python3.10/dist-packages (from pre-commit<3.0.0,>=2.12.1->pretty-confusion-matrix) (5.0.1)
Collecting virtualenv>=20.10.0 (from pre-commit<3.0.0,>=2.12.1->pretty-confusion-matrix)
```

(b)

Gambar 4. Proses Pelatihan (a) dan Evaluasi Data (b)

Setelah diperoleh hasil pelatihan yang terbaik, dilakukan proses pengujian data sehingga akan dihasilkan penelitian yang komprehensi seperti ditunjukkan oleh Gambar 5.

Confusion matrix									
Predicted	ewaste	52 4.33%			1 0.08%			2 0.17%	55 94.55% 5.45%
	leaf_waste		225 18.75%	3 0.25%	3 0.25%			1 0.08%	232 96.98% 3.02%
	paper_waste		2 0.17%	391 32.58%	1 0.08%	1 0.08%		2 0.17%	397 98.49% 1.51%
	plastic_bottles				69 5.75%	1 0.08%		17 1.42%	88 78.41% 21.59%
	food_waste					188 15.67%		10 0.83%	199 94.47% 5.53%
	metal_cans						52 4.33%		61 85.25% 14.75%
	plastic_bags							103 8.58%	105 98.10% 1.90%
	wood_waste	2 0.17%				8 0.67%		53 4.42%	63 84.13% 15.87%
	sum_col	54 96.30% 3.70%	229 98.25% 1.75%	394 99.24% 0.76%	69 100% 0.00%	212 88.68% 11.32%	53 98.11% 1.89%	130 79.23% 20.77%	59 89.83% 10.17%
		Actual							
		ewaste	leaf_waste	paper_waste	plastic_bottles	food_waste	metal_cans	plastic_bags	wood_waste

Gambar 5. Confusion matrix algoritma terlatih pada dataset pengujian

Matriks konfusi dan analisis akurasi pada model klasifikasi limbah yang Anda berikan memberikan gambaran yang baik tentang kinerja model. Mari kita tinjau beberapa poin kunci:

- Akurasi keseluruhan sebesar 94,42% menunjukkan bahwa model secara umum memiliki kinerja yang baik dalam mengklasifikasikan sampel limbah.
- Akurasi Tinggi pada Beberapa Kelas. Model menunjukkan akurasi yang tinggi untuk limbah kayu (99,24%), kantong plastik (98,10%), dan limbah daun (98,49%). Ini menandakan bahwa model sangat baik dalam mengidentifikasi kelas-kelas ini.
- Tantangan pada Kelas Tertentu. Terdapat beberapa kesulitan pada pengklasifikasian kaleng logam (85,25%) dan limbah makanan (94,47%). Hal ini dapat disebabkan oleh perbedaan yang lebih sulit untuk dikenali dalam karakteristik atau fitur antara kelas-kelas ini.
- Kemungkinan Kesalahan Klasifikasi. Model cenderung salah mengklasifikasikan limbah kayu sebagai kantong plastik sebesar 1,75%, dan kantong plastik sebagai limbah kayu sebesar 1,90%. Hal ini bisa menjadi area yang perlu perhatian lebih lanjut dalam pengembangan model.

- e. Tantangan dalam Klasifikasi Kaleng Logam dan Limbah Makanan. Model memiliki kesulitan khusus dalam mengklasifikasikan kaleng logam sebagai limbah makanan (14,75%) dan limbah makanan sebagai kaleng logam (5,53%). Ini menunjukkan adanya potensi peningkatan kinerja pada pengklasifikasian antara kelas ini.

Analisis seperti ini dapat membantu peneliti atau praktisi untuk memahami kekuatan dan kelemahan model, dan memandu upaya perbaikan atau penyesuaian yang mungkin diperlukan untuk meningkatkan kinerjanya pada kelas-kelas tertentu. Adapun performa masing-masing kelas dijelaskan pada Gambar 6 di bawah ini.

	precision	recall	f1-score	support
0	0.95	0.96	0.95	54
1	0.97	0.98	0.98	229
2	0.98	0.99	0.99	394
3	0.78	1.00	0.88	69
4	0.94	0.89	0.91	212
5	0.85	0.98	0.91	53
6	0.98	0.79	0.88	130
7	0.84	0.90	0.87	59
accuracy			0.94	1200
macro avg	0.91	0.94	0.92	1200
weighted avg	0.95	0.94	0.94	1200

Gambar 6. Nilai Performa Setiap Kelas

Dari Gambar 6 di atas, kelas 0 sampai kelas 7 dirinci secaraurut kelasnya, seperti sampah elektronik, daun, kertas, botol plastik, makanan, logam, tas plastik, kayu. Baris pertama tabel menunjukkan metrik klasifikasi untuk setiap kelas. Misalnya, baris pertama menunjukkan bahwa presisi untuk kelas e-waste adalah 0,95, recall untuk kelas e-waste adalah 0,96, dan F1-score untuk kelas e-waste adalah 0,95. Dukungan untuk kelas e-waste adalah 54. Baris terakhir tabel menunjukkan metrik klasifikasi rata-rata untuk semua kelas. Misalnya, baris terakhir menunjukkan bahwa presisi rata-rata adalah 0,91, recall rata-rata adalah 0,94, dan F1-score rata-rata adalah 0,94. Dukungan rata-rata adalah 1200. Tabel ini menunjukkan bahwa model klasifikasi sampah memiliki kinerja yang sangat baik. Model ini mencapai presisi rata-rata 0,91, recall rata-rata 0,94, dan F1-score rata-rata 0,94.

Secara keseluruhan, model mampu mengklasifikasikan limbah dengan tingkat akurasi yang tinggi. Namun, masih ada ruang untuk perbaikan, terutama dalam klasifikasi kaleng logam dan limbah makanan. Salah satu alasan mungkin untuk kesulitan model dalam mengklasifikasikan kaleng logam dan limbah makanan adalah bahwa kedua jenis limbah ini seringkali mirip dalam penampilan. Sebagai contoh, kaleng aluminium dan kaleng makanan mungkin keduanya memiliki kilauan logam. Demikian pula, limbah makanan dan kompos mungkin keduanya berwarna coklat dan bersifat organik.

Alasan lain mungkin untuk kesulitan model dalam mengklasifikasikan kaleng logam dan limbah makanan adalah bahwa kedua jenis limbah ini sering terkontaminasi dengan jenis limbah lain. Sebagai contoh, kaleng logam mungkin mengandung limbah makanan, atau sampel limbah makanan mungkin mengandung kantong plastik. Hal ini dapat membuat sulit bagi model untuk mengidentifikasi jenis utama limbah dalam sampel tersebut.

Penelitian masa depan dapat fokus pada pengembangan metode baru untuk meningkatkan klasifikasi kaleng logam dan limbah makanan. Sebagai contoh, para peneliti dapat mengembangkan algoritma pembelajaran mesin baru yang khusus dirancang untuk mengklasifikasikan kedua jenis limbah ini. Selain itu, para peneliti dapat mengembangkan metode baru untuk membersihkan dan menyiapkan sampel limbah sebelum diklasifikasikan. Hal ini dapat membantu mengurangi jumlah kontaminasi dalam sampel dan memudahkan model untuk mengidentifikasi jenis utama limbah.

4. Kesimpulan dan Saran

Telah dilakukan penelitian “Aplikasi Kecerdasan Artifisial dalam Klasifikasi Sampah sebagai Upaya Pengolahan Sampah Plastik” hingga proses pelatihan data. Pemilihan metode sesuai dengan kelebihan/keunggulan metode dari hasil tinjauan pustaka yang digunakan. Sesuai dataset yang ada, akan dilakukan identifikasi sampah yang akan digunakan, yaitu sampah sisa makanan, kertas, kayu, dan daun serta sampah elektronik, logam, plastic, dan botol. Akurasi keseluruhan model adalah 94,42%, yang berarti bahwa model tersebut mengklasifikasikan dengan benar 94,42% sampel limbah. Penelitian masa depan dapat fokus pada pengembangan metode baru untuk meningkatkan klasifikasi kaleng logam dan limbah makanan. Sebagai contoh, para peneliti dapat mengembangkan algoritma pembelajaran mesin baru yang khusus dirancang untuk mengklasifikasikan kedua jenis limbah ini.

Daftar Pustaka

- [1] L. dan B. Direktorat Jenderal Pengelolaan Sampah and D. P. Sampah, “CAPAIAN KINERJA PENGELOLAAN SAMPAH,” *Kehutanan, Kementerian Lingkungan Hidup dan*, 2023.
- [2] A. T. Setiawan, “Identifikasi Jenis Sampah Secara Otomatis Menggunakan Metode Convolutional Neural Network (CNN),” *Smart Comp*, vol. 11, no. 3, pp. 345–357, 2022.
- [3] A. Dinda Clasissa Aulia, Harry Kiswanto Situmorang, Ahmad Fauzy Habiby Prasetya, Adhe Fadilla, I. Safira Nisa, Asiyah Khoirunnisa, Deo Farhan, Dwi Nur’aini Nindya, Hanisa Purwantari, R. F. L. Octaviani Dwi Jasmin, Johninda Aulia Akbar, Novi Mesrina Cicionta BR Ginting, and Z. P. G, “Peningkatan Pengetahuan dan Kesadaran Masyarakat tentang Pengelolaan Sampah dengan Pesan Jepang,” *J. Pengabd. Kesehat. Masy.*, vol. 1, no. 1, pp. 62–70, 2021.
- [4] K. R. M. Gobai, B. Surya, and Syafri, *PENGELOLAAN SAMPAH PERKOTAAN*. 2021.
- [5] I. Buyung, A. Q. Munir, N. W. S., and L. Listyalina, “Identifying Types of Waste as Efforts in Plastic Waste Management Based on Deep Learning,” *Telemat. J. Inform. dan Teknol. Inf.*, vol. 20, no. 3, pp. 362–372, 2023.
- [6] L. et al Listyalina, “Deep-RIC: Plastic Waste Classification using Deep Learning and

- Resin Identification Codes (RIC).,” *Telemat. J. Inform. dan Teknol. Inf.*, vol. 19, no. 2, pp. 215–228, 2022.
- [7] G. AashiDutt, “Waste Segregation Image Dataset,” *Kaggle*, 2023.
- [8] A. Dinda Clasissa Aulia, Harry Kiswanto Situmorang, Ahmad Fauzy Habiby Prasetya, Adhe Fadilla, I. Safira Nisa, Asiyah Khoirunnisa, Deo Farhan, Dwi Nur’aini Nindya, Hanisa Purwantari, R. F. L. Octaviani Dwi Jasmin, Johninda Aulia Akbar, Novi Mesrina Cicionta BR Ginting, and Z. P. G, “Peningkatan Pengetahuan dan Kesadaran Masyarakat tentang Pengelolaan Sampah dengan Pesan Jepang,” *J. Pengabd. Kesehat. Masy.*, vol. 1, no. 1, 2021.
- [9] I. G. M. A. I Made Pageh, “Solusi Strategis Penangan Masalah Sampah Dengan Mengolah Sampah Dapur Menjadi Pupuk Organik Cair (POC): (Kasus Dua Desa Pinggir Kota di Kota Singaraja Bali,” *J. Ilm. Ilmu Sos.*, vol. 4, no. 2, pp. 175–180, 2018.
- [10] A. C. Malina, Suhasman, A. Muchtar, and Sulfahri, “KAJIAN LINGKUNGAN TEMPAT PEMILAHAN SAMPAH DI KOTA MAKASSAR,” *J. Inov. dan Pelayanan Publik Makassar*, vol. 1, no. 1, 2017.
- [11] M. I. Utami and dan D. E. A. F. Ningrum, “Proses Pengolahan Sampah Plastik di UD Nialdho Plastik Kota Madiun,” *Indones. J. Conserv.*, vol. 9, no. 2, pp. 89–95, 2020.
- [12] F. D. A. Abdurrahman Ibnul Rasidi, Yolanda Al Hidayah Pasaribu, Afzal Ziqri, “Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network,” *J. Tek. dan Sist. Inf.*, vol. 8, no. 1, pp. 142–149, 2022.
- [13] F. U. Rahmatul Bijak Nur Kholis, “Rancang Bangun Sistem Klasifikasi Sampah Anorganik Kantor menggunakan Deep Learning Arsitektur Xceptionberbasis NVIDIA Jetson Nano,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 6, pp. 2681–2686, 2022.
- [14] P. H. U. Octavia Devi Safitri Sunanto, “IMPLEMENTASI DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI GAMBAR SAMPAH ORGANIK DAN ANORGANIK,” in *Seminar Nasional Matematika, Geometri, Statistika, dan KomputasiSeNa-MaGeStiK 2022*, 2022, pp. 373–382.
- [15] H. Tantri Indrabulan, “KLASIFIKASI SAMPAH PLASTIK BERDASARKAN KEPAKARAN AHLI MENGGUNAKAN METODE K-NEAREST NEIGHBOR,” *J. Inform. AINET*, vol. 4, no. 1, pp. 6–15, 2022.